



یادگیری عمیق

جلسه ۱۲

مبانی یادگیری ماشینی (۲)

Fundamentals of Machine Learning (2)

کاظم فولادی قلعه

دانشکده مهندسی، پردیس فارابی

دانشگاه تهران

<http://courses.fouladi.ir/deep>

یادگیری عمیق

مبانی یادگیری ماشینی

۱

یادگیری ماشینی

صورت‌های یادگیری ماشینی

FORMS OF MACHINE LEARNING

صورت‌های یادگیری	
یادگیری استنباطی <i>Deductive Learning</i>	یادگیری استقرائی <i>Inductive Learning</i>
یادگیری کل به جزء	یادگیری جزء به کل
یادگیری تحلیلی <i>Analytical Learning</i>	یادگیری یک تابع یا قاعده‌ی عمومی (درست/نادرست) از روی جفت‌های خاص ورودی - خروجی / مثال‌ها
حرکت از یک قاعده‌ی عمومی شناخته‌شده به قاعده‌ی جدیدی که منطقاً استلزم می‌شود. (مفید است، زیرا امکان پردازش کارآمدتر را فراهم می‌کند.)	

صورت‌های یادگیری ماشینی

یادگیری استقرائی

یادگیری استقرائی *Inductive Learning*

یادگیری جزء به کل

یادگیری یک تابع یا قاعده‌ی عمومی (درست/نادرست)
از روی جفت‌های خاص ورودی - خروجی / مثال‌ها

یادگیری خودنظرارتی <i>Self-Supervised</i>	یادگیری نیمه‌نظرارتی <i>Semisupervised</i>	یادگیری تقویتی <i>Reinforcement</i>	یادگیری بی‌نظرارت <i>Unsupervised</i>	یادگیری بانظرارت <i>Supervised</i>
یادگیری بانظرارت بدون استفاده از برچسب‌های تهیه شده توسط انسان / برچسب‌ها از روی داده‌های ورودی تولید می‌شوند.	یادگیری با وجود تعداد کمی مثال برچسب‌دار و مجموعه‌ی بزرگی از داده‌های بی‌برچسب	یادگیری از روی یک سری تقویت‌ها (پاداش‌ها و جریمه‌ها)	یادگیری الگوهای درون ورودی بدون وجود فیدبک صریح (clustering) (مثل	یادگیری نگاشت ورودی به خروجی با دیدن مثال‌های برچسب‌دار

تقسیم‌بندی بر اساس نوع فیدبک موجود برای یادگیری

سه نوع اصلی یادگیری

شاخه‌های یادگیری ماشینی

یادگیری بانظارت

یادگیری بانظارت، رایج‌ترین شکل یادگیری ماشینی است:
یادگیری نگاشت داده‌های ورودی به تارگت‌های معلوم
بر اساس مجموعه‌ای از مثال‌های داده شده

عموماً، تقریباً تمامی کاربردهای درخشنان یادگیری عمیق، از نوع یادگیری بانظارت هستند.

مانند:

بازشناسی نوری حروف، بازشناسی گفتار، طبقه‌بندی تصاویر، ترجمه‌ی زبان

شاخه‌های یادگیری ماشینی

یادگیری بانظارت

SUPERVISED LEARNING

یادگیری بانظارت

Supervised Learning

یک مجموعه‌ی آموزشی از N جفت ورودی-خروجی نمونه داده شده است:

$$(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$$

که در آن هر y_j به وسیله‌ی یک تابع مجهول f تولید شده است:

$$y = f(x)$$

یک تابع h را کشف کنید که تابع واقعی f را تقریب بزند.

شاخه‌های یادگیری ماشینی

یادگیری بانظارت: مفاهیم کلیدی

یادگیری بانظارت

Supervised Learning

مجموعه‌ی جفت‌های ورودی-خروجی معلوم برای آموزش یادگیرنده

مجموعه‌ی آموزشی
Training Set

مجموعه‌ی جفت‌های ورودی-خروجی معلوم برای آزمایش یادگیرنده

مجموعه‌ی آزمایشی
Test Set

تابع f که باید یاد گرفته شود

هدف / تارگت
Target

تابع مجهول h که باید تقریب مناسبی برای f باشد

فرضیه
Hypothesis

مجموعه‌ی همه‌ی توابع منتخب h برای تقریب f

فضای فرضیه
Hypothesis Space

\mathcal{H}

شاخه‌های یادگیری ماشینی

دو دسته‌ی مهم از مسائل یادگیری بانظارت: طبقه‌بندی و رگرسیون

یادگیری بانظارت
Supervised Learning

طبقه‌بندی
Classification

رگرسیون
Regression

وقتی خروجی y از یک مجموعه‌ی متناهی مشخص انتخاب شود.

وقتی خروجی y یک عدد باشد (یافتن امید شرطی یا متوسط y)

شاخه‌های یادگیری ماشینی

نمونه‌هایی از کاربردهای یادگیری بانظارت

پیش‌بینی یک شرح برای توصیف یک تصویر داده شده
تولید دنباله اغلب می‌تواند به صورت یک سری از مسائل طبقه‌بندی فرمول‌بندی شود.

تولید دنباله

Sequence Generation

پیش‌بینی تجزیه‌ی یک جمله‌ی داده شده به درخت نحو آن

پیش‌بینی درخت نحو

Syntax Tree Prediction

رسم یک چهارگوش دور اشیای خاص داخل یک تصویر داده شده
آشکارسازی اشیا می‌تواند به صورت یک مسئله‌ی طبقه‌بندی بیان شود
(چهارگوش‌های کاندیدای متفاوت، طبقه‌بندی محتوای هر یک)
یا مسئله‌ی طبقه‌بندی و رگرسیون توأم (رگرسیون برداری برای تعیین مختصات گوشها)


آشکارسازی اشیا

Object Detection

رسم یک ماسک در سطح پیکسل بر روی یک شیء خاص در یک تصویر داده شده

بخش‌بندی تصویر

Image Segmentation



آشکارسازی اشیا
Object Detection

بخشندی تصویر
Image Segmentation



sky tree road grass water bldg mtn fg obj.

شاخه‌های یادگیری ماشینی

یادگیری بدون ناظارت

UNSUPERVISED LEARNING

در یادگیری بدون ناظارت،

یادگیری حاوی یافتن تبدیل‌های مفید داده‌های ورودی بدون کمک گرفتن از هرگونه تارگت است.

اهداف: بصری‌سازی داده‌ها، فشرده‌سازی داده‌ها، نویز‌زدایی از داده‌ها، درک بهتر از همبستگی موجود در داده‌ها

یادگیری بی‌ناظارت، معمولاً یک گام لازم برای فهم بهتر یک مجموعه داده پیش از تلاش برای حل یک مسئله‌ی یادگیری با ناظارت است.

کاهش ابعاد (dimensionality reduction) و خوشبندی (clustering)

دو مسئله‌ی معروف در یادگیری بی‌ناظارت هستند.

شاخه‌های یادگیری ماشینی

یادگیری خود ناظارتی

SELF-SUPERVISED LEARNING

نوع خاصی از یادگیری با ناظارت است که در آن از برچسب‌های تولید شده توسط انسان استفاده نمی‌شود.

در این نوع از یادگیری، برچسب وجود دارد،
اما برچسب‌ها از روی داده‌های ورودی و معمولاً با استفاده از یک الگوریتم هیوریستیک تولید می‌شوند.

برای مثال: خودکذارها (autoencoders). نمونه‌ی معروفی از یادگیری خودناظارتی هستند
که در آنها تارگت‌های تولید شده همان ورودی‌ها بدون هیچ تغییری هستند.

پیش‌بینی فریم بعدی در یک ویدئو با داشتن فریم‌های قبلی،
پیش‌بینی کلمه‌ی بعدی در یک متن با داشتن کلمات قبلی
یادگیری با ناظارت زمانی (temporally supervised learning): داده‌های ناظارت از آینده‌ی داده‌های ورودی می‌آیند.

شاخه‌های یادگیری ماشینی

یادگیری تقویتی

REINFORCEMENT LEARNING

یادگیری تقویتی،

عامل اطلاعاتی در مورد محیط خود دریافت می‌کند و
یاد می‌گیرد بهترین کنش‌هایی را انتخاب کند که پاداش او را حداکثر می‌سازد.

برای مثال:

یک شبکه‌ی عصبی که به صفحه‌ی یک بازی ویدئویی نگاه می‌کند و کنش‌های بازی را در خروجی تحويل می‌دهد،
به‌گونه‌ای که امتیاز آن حداکثر شود، می‌تواند با یادگیری تقویتی آموزش داده شود.

در حال حاضر یادگیری تقویتی بیشتر یک زمینه‌ی پژوهشی است و خارج از زمینه‌ی بازی‌ها
(مانند یادگیری بازی‌های آتاری [Google DeepMind] یا بازی Go) موفقیت عملی چشمگیری نداشته است.

انتظار می‌رود موفقیت یادگیری تقویتی در حوزه‌ی گسترده‌ای از کاربردهای دنیا واقعی دیده شود، مانند:
خودروهای خودران، رباتیک، مدیریت منابع، تربیت و ...

مبانی یادگیری ماشینی

۳

ارزیابی مدل‌های یادگیری ماشینی

ارزیابی مدل‌های یادگیری ماشینی

EVALUATING MACHINE-LEARNING MODELS

هدف در یادگیری ماشینی، دستیابی به مدل‌هایی است که قابلیت تعمیم (generalization) داشته باشند [یعنی بتوانند بر روی داده‌هایی که هرگز آنها را ندیده‌اند، به خوبی عمل کنند] و بیشبرازش (overfitting) مانع اصلی در قبال این موضوع است.

از آنجا که ما تنها می‌توانیم چیزی را کنترل کنیم که بتوانیم آن را مشاهده کنیم، ضروری است که قادر باشیم قدرت تعمیم یک مدل را به طور مطمئن اندازه‌گیری کنیم.




چگونگی اندازه‌گیری تعمیم \Leftarrow چگونگی ارزیابی یک مدل یادگیری ماشین

ارزیابی مدل‌های یادگیری ماشینی

مجموعه‌های آموزشی، اعتبارسنجی، آزمایشی

TRAINING, VALIDATION, AND TEST SETS

مجموعه‌ی داده‌ها را به سه زیرمجموعه تقسیم می‌کنیم:



فرآیند آموزش روی داده‌های آموزشی انجام می‌شود.
مدل بر اساس داده‌های اعتبارسنجی ارزیابی می‌شود.
پس از آماده شدن مدل، برای آخرین بار روی داده‌های آزمایشی مورد آزمون و بررسی قرار می‌گیرد.

ارزیابی مدل‌های یادگیری ماشینی

چرا فقط از دو مجموعه‌ی آموزشی و آزمایشی استفاده نکنیم؟

چرا فقط از دو مجموعه‌ی آموزشی و آزمایشی استفاده نکنیم؟

زیرا:

توسعه‌ی یک مدل همیشه حاوی تنظیم پیکربندی آن است،
 (مانند: انتخاب تعداد لایه‌ها، اندازه‌ی لایه‌ها، ... [هایپرپارامترها: hyperparameters])

تنظیم این پارامترها با استفاده از یک سیگنال فیدبک کارآیی شبکه روی داده‌های اعتبارسنجی انجام می‌شود.
 خود این تنظیم نوعی یادگیری است که با استفاده از داده‌های اعتبارسنجی انجام شده است.

هرگاه هایپرپارامتری از مدل را بر اساس کارآیی آن روی مجموعه‌ی اعتبارسنجی تنظیم می‌کنیم، مقداری اطلاعات در مورد داده‌های اعتبارسنجی به مدل نشت می‌کند.

نشت اطلاعاتی
Information Leaks

بنابراین باید از یک مجموعه داده‌ی کاملاً متفاوت که قبلاً هرگز مشاهده نشده است برای آزمایش مدل استفاده کنیم:
مجموعه‌ی آزمایشی.

مدل نباید به هیچ گونه اطلاعاتی در مورد این مجموعه‌ی آزمایشی دسترسی داشته باشد (حتی به طور غیرمستقیم).

ارزیابی مدل‌های یادگیری ماشینی

روش‌های اعتبارسنجی

تقسیم داده‌ها به مجموعه‌های آموزشی، اعتبارسنجی، آزمایشی به نظر سرراست می‌رسد، اما روش‌های پیشرفته‌ای وجود دارد که زمانی که داده‌های کمی موجود است مفید واقع می‌شوند.

اعتبارسنجی ساده نگه‌داشت - برون‌گذاشت




Simple Hold-Out Validation

اعتبارسنجی *K-fold*

K-fold Validation

اعتبارسنجی *K-fold* تکراری با بُر زدن

Iterated K-fold Validation with Shuffling




ارزیابی مدل‌های یادگیری ماشینی

اعتبارسنجی ساده نگهداشت-برونگذاشت

SIMPLE HOLD-OUT VALIDATION

بخشی از داده‌های آموزشی را به منظور اعتبارسنجی جدا می‌کنیم.



این ساده‌ترین پروتکل ارزیابی است و از یک نقیصه رنج می‌برد:
 اگر داده‌های اندکی موجود باشد، آن‌گاه مجموعه‌های اعتبارسنجی و آزمایشی ممکن است
 حاوی تعداد نمونه‌های بسیار کمی برای نمایندگی آماری داده‌ها باشند.

ارزیابی مدل‌های یادگیری ماشینی

اعتبارسنجی ساده نگهداشت-برونگذاشت

Hold-out validation

```
num_validation_samples = 10000
```

Shuffling the data is
usually appropriate.

```
np.random.shuffle(data) <
```

Defines the
validation set

```
validation_data = data[:num_validation_samples] <
```

Defines the
training set

```
data = data[num_validation_samples:]
```

```
training_data = data[:] <
```

```
model = get_model()  
model.train(training_data)  
validation_score = model.evaluate(validation_data)
```

Trains a model on the
training data, and evaluates
it on the validation data

```
# At this point you can tune your model,  
# retrain it, evaluate it, tune it again...
```

```
model = get_model()  
model.train(np.concatenate(  
    [training_data, validation_data]))  
  
test_score = model.evaluate(test_data)
```

Once you've tuned your
hyperparameters, it's common to
train your final model from
scratch on all non-test data
available.


ارزیابی مدل‌های یادگیری ماشینی

اعتبارسنجی K-fold

K-FOLD VALIDATION

داده‌های موجود را به K سلول با اندازه‌ی مساوی افزای می‌کنیم (معمولاً $K = 4, 5$)، برای هر سلول i ، یک مدل را بر روی $1 - K - i$ سلول باقیمانده آموزش می‌دهیم و آن را روی سلول i ارزیابی می‌کنیم.

امتیاز نهایی اعتبارسنجی مدل = متوسط K امتیاز اعتبارسنجی حاصل.



این روش زمانی کمک کننده است که کارآئیی مدل ما واریانس بالایی بر اساس تقسیم آموزش-آزمایش داشته باشد. این روش مانند روش ساده، ما را از به کارگیری یک مجموعه‌ی اعتبارسنجی مجزا برای کالیبراسیون مدل معاف نمی‌کند.

ارزیابی مدل‌های یادگیری ماشینی

اعتبارسنجی K-fold

K-fold cross validation

```

k = 4
num_validation_samples = len(data) // k

np.random.shuffle(data)

validation_scores = []

for fold in range(k):
    validation_data = data[num_validation_samples * fold:
                           num_validation_samples * (fold + 1)]
    training_data = data[:num_validation_samples * fold] +
                   data[num_validation_samples * (fold + 1):] <-- Selects the validation data partition

    model = get_model() <-- Creates a brand-new instance of the model (untrained)
    model.train(training_data)
    validation_score = model.evaluate(validation_data)
    validation_scores.append(validation_score)

validation_score = np.average(validation_scores) <-- Validation score: average of the validation scores of the k folds

model = get_model()
model.train(data)
test_score = model.evaluate(test_data)
    
```

Uses the remainder of the data as training data. Note that the + operator is list concatenation, not summation.

Trains the final model on all non-test data available

ارزیابی مدل‌های یادگیری ماشینی

اعتبارسنجی K-fold تکراری با بُر زدن

ITERATED K-FOLD VALIDATION WITH SHUFFLING

استفاده از اعتبارسنجی K-fold به تعداد P مرتبه و بُر زدن (shuffling) داده‌ها در هر مرتبه پیش از تقسیم آن به K قسمت.

امتیاز نهایی = متوسط امتیازهای کسب شده در هر مرتبه از اجرای اعتبارسنجی K-fold

در پایان تعداد $K \times P$ مدل تحت آموزش و ارزیابی قرار گرفته است، که می‌تواند بسیار پرهزینه باشد.

این روش مختص موقعیت‌هایی است داده‌های اندکی در اختیار داریم و نیاز داریم مدل با حداقل دقت ممکن ارزیابی شود.

ارزیابی مدل‌های یادگیری ماشینی

نکات مهم

هم مجموعه‌ی آموزشی و هم مجموعه‌ی آزمایشی باید نماینده‌ی همه‌ی داده‌های موجود باشند (از همه‌ی کلاس‌ها به تعداد کافی در هر دو موجود باشد).

لازم است پیش از تقسیم داده‌ها بین مجموعه‌های آموزش و آزمایش آنها را به صورت تصادفی بر بزنیم (randomly shuffle).

نماینده‌گی داده‌ها

Data Representativeness



اگر هدف حل یک مسئله‌ی پیش‌بینی آینده بر اساس گذشته است، باید پیش از تقسیم داده‌ها آنها را بر بزنیم و ترتیب آنها تصادفاً تغییر دهیم (این کار موجب نشت زمانی (temporal leak) می‌شود و باعث می‌شود مدل بر روی داده‌هایی از آینده آموزش ببیند).

در چنین مواردی باید مطمئن بود که همه‌ی داده‌های آزمایشی، از نظر زمانی پس از داده‌های آموزشی قرار داشته باشند.

پیکان زمان

The Arrow of Time



اگر برخی نقاط داده‌ای چند بار ظاهر شده باشند، بر زدن آنها و تقسیم آنها به مجموعه‌های آموزشی و اعتبارسنجی، موجب بروز افزونگی بین این دو مجموعه می‌شود. در نتیجه، تست روی بخشی از داده‌های آموزش انجام می‌شود (بدترین کار ممکن).

باید مطمئن باشیم که مجموعه‌های آموزشی و اعتبارسنجی مجزا باشند.

افزونگی در داده‌ها

Redundancy in the Data





یادگیری عمیق

جلسه ۱۲

مبانی یادگیری ماشینی (۲)

Fundamentals of Machine Learning (2)

کاظم فولادی قلعه

دانشکده مهندسی، پردیس فارابی

دانشگاه تهران

<http://courses.fouladi.ir/deep>

مبانی یادگیری ماشینی

۳

پیش‌پردازش
داده‌ها،
مهندسی
ویژگی‌ها،
یادگیری
ویژگی‌ها

پیش‌پردازش داده‌ها، مهندسی ویژگی‌ها، یادگیری ویژگی‌ها

DATA PREPROCESSING, FEATURE ENGINEERING, AND FEATURE LEARNING

چگونه باید داده‌های ورودی و تارگت‌ها را برای خوراندن به شبکه‌های عصبی آماده کنیم؟

بسیاری از تکنیک‌های پیش‌پردازش داده‌ها و مهندسی ویژگی‌ها، مختص به یک حوزه‌ی خاص هستند
(مانند: داده‌های متنی یا داده‌های تصویری، ...)

در اینجا، پایه‌های مشترک بین تمامی حوزه‌های داده‌ای بررسی می‌شوند.

پیش‌پردازش داده‌ها برای شبکه‌های عصبی

DATA PREPROCESSING FOR NEURAL NETWORKS

هدف از پیش‌پردازش داده‌ها، مناسب‌تر سازی داده‌های موجود برای شبکه‌های عصبی است.




پیش‌پردازش داده‌ها برای شبکه‌های عصبی

برداری‌سازی

VECTORIZATION

برداری‌سازی

Vectorization



تمام ورودی‌ها و تارگت‌ها در شبکه‌های عصبی باید به
タンسورهایی از **داده‌های ممیز شناور** (یا در موارد خاص اعداد صحیح)
تبديل شوند.

مانند: کدگذاری تک- DAG برای کلمات و ...

پیش‌پردازش داده‌ها برای شبکه‌های عصبی

نرمال‌سازی

NORMALIZATION

نرمال‌سازی

Normalization

به طور کلی، خوراندن داده‌هایی که مقادیر نسبتاً بزرگی دارند یا داده‌های ناهمگن به یک شبکه‌ی عصبی، کار چندان ایمنی نیست.
 (انجام این کار می‌تواند موجب تحریک به روزرسانی گرادیانی بزرگی شود که از همگرا شدن شبکه جلوگیری می‌کند.)

ویژگی‌های ضروری داده‌ها
 برای
 یادگیری ساده تر
 توسط شبکه‌های عصبی

- مقادیر کوچک (small values) : اکثر داده‌ها باید در بازه‌ی [0,1] باشند.
- مقادیر همگن (homogenous) : همه‌ی ویژگی‌ها باید مقادیری در بازه‌های تقریباً مشابه داشته باشند.

روش‌های زیر برای نرمال‌سازی قوی‌تر (استانداردسازی) در عمل متداول است، اما همیشه ضروری نیست:

```
x -= x.mean(axis=0)
x /= x.std(axis=0)
```

- نرمال‌سازی هر ویژگی به‌طور مستقل تا میانگین آن **صفر** شود.
- نرمال‌سازی هر ویژگی به‌طور مستقل تا انحراف استاندارد آن **یک** شود.

نرمال سازی داده ها

تکنیک ها

DATA NORMALIZATION: TECHNIQUES

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)}$$

باز مقیاس دهی (نرمال سازی)
Rescaling (Min-Max Normalization)

$$x' = \frac{x - \text{average}(x)}{\max(x) - \min(x)}$$

نرمال سازی با میانگین
Mean Normalization

$$x' = \frac{x - \text{average}(x)}{\text{std}(x)}$$

استاندارد سازی
Standardization


پیش‌پردازش داده‌ها برای شبکه‌های عصبی

برخورد با مقادیر گمشده

HANDLING MISSING VALUES

برخورد با مقادیر گمشده

Handling Missing Values



در برخی موارد ممکن است مقادیر برخی از ویژگی‌ها در برخی از نمونه‌ها موجود نباشد (قدار گمشده).

در شبکه‌های عصبی، روش ایمن این است که مقدار داده‌های ورودی ناموجود را برابر با صفر قرار دهیم. به شرط آنکه صفر یک مقدار معنادار نباشد.

شبکه هنگام مواجهه با داده‌ای که مقدار آن برابر با صفر است، یاد می‌گیرد که صفر به معنی داده‌ی ناموجود است و شروع به نادیده گرفتن آنها می‌کند.

نکته: اگر انتظار می‌رود مقادیر گمشده در داده‌های آزمایشی وجود داشته باشد، اما شبکه با داده‌هایی فاقد هرگونه مقدار گمشده آموزش دیده باشد، آن‌گاه این شبکه روش نادیده گرفتن مقادیر گمشده را نخواهد آموخت!

در این موارد باید به صورت مصنوعی نمونه‌های آموزشی دارای درایه‌های گمشده را تولید کنیم: چند نمونه‌ی آموزشی را چند بار کپی می‌کنیم و چند ویژگی که در برخی داده‌های آزمایشی وجود ندارد را حذف می‌کنیم.


پیش‌پردازش داده‌ها برای شبکه‌های عصبی

مهندسی ویژگی‌ها

FEATURE ENGINEERING

استخراج ویژگی

Feature Extraction



در مهندسی ویژگی‌ها،

از دانایی موجود در مورد داده‌ها و الگوریتم یادگیری ماشینی مورد نظر (در اینجا شبکه‌های عصبی) استفاده می‌شود و تبدیل‌هایی بر روی داده‌ها پیش از ورود به مدل از طریق کدنویسی اعمال می‌شود تا موجب بهبود عملکرد الگوریتم شود.

در بسیاری از موارد، منطقی نیست که توقع داشته باشیم یک مدل یادگیری ماشینی قادر باشد از داده‌های کاملاً دلخواه یاد بگیرد.

داده‌ها باید به شیوه‌ای به مدل ارائه شوند که کار مدل را ساده‌تر کنند.


پیش‌پردازش داده‌ها برای شبکه‌های عصبی

مهندسی ویژگی: مثال (خواندن زمان از روی یک ساعت)

فرض می‌کنیم می‌خواهیم مدلی توسعه بدهیم که تصویر یک ساعت را به عنوان ورودی دریافت کند و **زمان روز** را به عنوان خروجی تحویل بدهد.

اگر پیکسل‌های خام تصویر را به عنوان ورودی در نظر بگیریم، یا یک مسئله‌ی دشوار یادگیری ماشینی سروکار خواهیم داشت.
(نیاز به CNN با منابع محاسباتی بالا و داده‌های آموزشی بسیار زیاد)

Raw data:
pixel grid



اگر این مسئله را در سطح بالا درک کنیم (روش خواندن زمان از روی ساعت توسط انسان‌ها) می‌توانیم ویژگی‌های ورودی بهتری برای الگوریتم یادگیری بیابیم (مثل: مختصات نوک عقربه‌ها)

Better features: clock hands' coordinates	$\{x1: 0.7, y1: 0.7\}$	$\{x1: 0.0, y1: 1.0\}$
	$\{x2: 0.5, y2: 0.0\}$	$\{x2: -0.38, y2: 0.32\}$

حتی می‌توانیم از مختصات قطبی استفاده کنیم که در این صورت ویژگی‌های لازم، زاویه‌ی هر عقربه است. در اینجا که به حدی ساده می‌شود که دیگر حتی نیازی به یادگیری ماشینی نیست!

Even better features: angles of clock hands	theta1: 45 theta2: 0	theta1: 90 theta2: 140
--	-------------------------	---------------------------

پیش‌پردازش داده‌ها برای شبکه‌های عصبی

مهندسی ویژگی: ضرورت

اساس مهندسی ویژگی‌ها: ساده‌ترسازی یک مسئله از طریق بیان آن به صورتی ساده‌تر

پیش از یادگیری عمیق، مهندسی ویژگی‌ها بسیار حیاتی بود، زیرا مدل‌های کم‌عمق فضاهای فرضیه‌ی به اندازه‌ی کافی غنی ندارند تا ویژگی‌های مفید را خودشان یادبگیرند؛ خوشبختانه، یادگیری عمیق مدرن نیاز به مهندسی را تا حد بسیاری حذف کرده است: زیرا این مدل‌ها قادر به استخراج خودکار ویژگی‌های سودمند از داده‌های خام هستند.

اما این به آن معنا نیست که در استفاده از شبکه‌های عصبی عمیق به مهندسی ویژگی‌ها نیازی نداریم.

- امکان حل مسائل به صورتی بهتر با استفاده از منابع کمتر با ویژگی‌های خوب
- امکان حل مسائل با حجم داده‌ی بسیار کمتر

دلایل نیاز به
مهندسي ویژگي‌ها
در یادگيری عميق

مبانی یادگیری ماشینی

۴

بیش برازش و کم برازش

بیشبرازش و کمبرازش

OVERFITTING AND UNDERFITTING

بیشبرازش در هر مسئله‌ی یادگیری ماشینی اتفاق می‌افتد.

درک چگونگی رویارویی با بیشبردازش برای تسلط بر یادگیری ماشینی ضروری است.

مسئله‌ی بنیادین در یادگیری ماشینی، کشمکش میان **بهینه‌سازی (سازگاری)** و **تعییم** است.

هدف این بازی رسیدن به تعییم خوب است،

اما ما تعییم را کنترل نمی‌کنیم، بلکه ما فقط می‌توانیم مدل را بر اساس داده‌های آموزشی تنظیم کنیم.

در ابتدای آموزش، بهینه‌سازی و تعییم با یکدیگر همبسته هستند:

هر چه اتلاف روی داده‌های آموزشی کمتر باشد، روی داده‌های آزمایشی هم کمتر است (و ضعیت **کمبرازش**).

اما پس از چند تکرار مشخص روی داده‌های آموزشی، بهبود تعییم متوقف می‌شود (شروع **بیشبرازش**).

مدل شروع می‌کند به یادگیری الگوهایی که مختص داده‌های آموزشی است (آنها را حفظ می‌کند)؛

اما هنگامی که داده‌های جدید مطرح می‌شوند، این الگوها گمراه‌کننده یا نامربوط هستند.

سازگاری و تعمیم

تعمیم

Generalization

یک فرضیه **تعمیم‌پذیر** است
اگر
مقادیر خروجی نمونه‌های جدید را
به درستی پیش‌بینی کند.

تعمیم مشخص می‌کند که مدل آموزش دیده
چه قدر خوب بر روی داده‌هایی که پیش از
این دیده نشده‌اند عمل می‌کند.

سازگاری

Consistency

یک فرضیه **سازگار** است
اگر
بر روی همه نمونه‌های آموزشی
درست باشد.

بهینه‌سازی به دنبال تنظیم یک مدل برای
دستیابی به بهترین کارآیی ممکن بر روی
داده‌های آموزشی است.

بدهستان میان سازگاری - تعمیم‌پذیری:
فرضیه‌های **پیچیده** با سازگاری کامل و فرضیه‌های **ساده‌تر** با تعمیم‌پذیری بالاتر

بیشبرازش و کمبرازش

OVERTFITTING AND UNDERFITTING

دقت مدل روی داده‌های آموزشی بیشتر از
دقت مدل روی داده‌های اعتبارسنجی شده است.

بیشبرازش
Overfitting

شبکه هنوز همه‌ی الگوهای مربوط در داده‌های آموزشی را مدل نکرده است.

کمبرازش
Underfitting

جلوگیری از بیشبرازش

رگولاریزاسیون

بهترین راه حل برای جلوگیری از بیشبرازش، استفاده از داده‌های بیشتر می‌باشد. مدلی که بر روی تعداد داده‌ی بیشتری آموزش دیده باشد، طبیعتاً تعمیم‌پذیری بالاتری خواهد داشت.

بهترین راه حل بعدی، تغییر کمیت اطلاعاتی است که مدل مجاز به ذخیره کردن آنهاست، یا اضافه کردن قیدها بر روی اطلاعاتی است که مدل مجاز به ذخیره کردن آنهاست.

اگر یک شبکه فقط برای حفظ کردن تعداد کوچکی از الگوهای توانایی داشته باشد، فرآیند بهینه‌سازی آن را مجبور خواهد کرد که بر روی برجسته‌ترین الگوها تمرکز کند، که این شناس سه برای تعمیم‌دهی بالاتر دارد.

فرآیند مقابله با بیشبرازش از طریق تغییر/منظم‌سازی وزن‌ها

رگولاریزاسیون
Regularization

تعمیم‌پذیر کردن شبکه‌های عصبی

برای ایجاد تعمیم‌پذیری، روی کرد کلی سعی در یافتن ساده‌ترین شبکه است که بر داده‌ها fit شود.

۱) محدود کردن تعداد وزن‌ها (تعداد نرون‌ها)

۲) محدود کردن اندازه‌ی وزن‌ها

توقف زودهنگام

Early Stopping

رگولاریزاسیون

Regularization

دو دسته‌ی کلی
از روش‌های
تعمیم‌پذیرسازی



تکنیک‌های رگولاریزاسیون

(منظم‌سازی)

REGULARIZATION TECHNIQUES


کاهش اندازه‌ی شبکه

Reducing the network's size



افزودن رگولاریزاسیون وزنی

Adding weight regularization



افزودن برون‌اندازی

Adding dropout



تکنیک‌های رگولاریزاسیون

کاهش اندازهٔ شبکه

REDUCING THE NETWORK'S SIZE

ساده‌ترین راه برای اجتناب از بیش‌برازش، کاهش **اندازهٔ مدل** است:
تعداد پارامترهای قابل یادگیری در مدل (تابعی از تعداد لایه‌ها و تعداد واحدها در هر لایه)

تعداد پارامترهای قابل یادگیری در مدل

ظرفیت مدل
Model's Capacity

مدلی که پارامترهای بیشتری دارد، **ظرفیت حفظ‌کردن** بیشتری دارد و بنابراین، به سادگی می‌تواند یک نگاشت دیکشنری مانند بین نمونه‌های آموزشی و تارگت آنها را یاد بگیرد، که یک نگاشت بدون هرگونه قدرت تعمیم است.
(به‌ویژه در مدل‌های عمیق که ظرفیت آنها بالاست)

از طرف دیگر، اگر شبکه منابع حفظ کردن محدودی داشته باشد، قادر نخواهد بود این نگاشت را به سادگی یاد بگیرد؛ پس برای می‌نیمسازی loss به سمت یادگیری بازنمایی‌های فشرده‌ای کشیده می‌شود که قدرت پیش‌بینی تارگت‌هارا داشته باشند.

تکنیک‌های رگولاریزاسیون

کاهش اندازهٔ شبکه: تعادل بین ظرفیت بسیار زیاد و ظرفیت ناکافی

مدل مورد استفاده باید تعداد کافی پارامتر داشته باشد تا دچار کم برآذش نشود.

یک وضعیت بد هبستان (مصلحه) وجود دارد
که باید بین ظرفیت بسیار زیاد و ظرفیت ناکافی پیدا شود.

هیچ فرمول جادویی برای تعیین تعداد درست لایه‌ها یا اندازهٔ درست هر لایه وجود ندارد.

برای یافتن اندازهٔ درست مدل، باید آرایه‌ای از معماری‌های مختلف روی مجموعهٔ اعتبارسنجی ارزیابی شود.

به طور کلی، برای یافتن اندازهٔ مناسب مدل،
از تعداد نسبتاً کمی لایه و پارامتر شروع می‌کنیم
و اندازهٔ لایه‌ها را اضافه می‌کنیم یا لایه‌های جدیدی اضافه می‌کنیم
تا با توجه به اتلاف روی داده‌های اعتبارسنجی، افت بازدهی را مشاهده کنیم.

تکنیک‌های رگولاریزاسیون

کاهش اندازهٔ شبکه: مثال (طبقه‌بندی نقد فیلم‌ها)

Original model (the movie-review classification network)


```
from keras import models
from keras import layers
model = models.Sequential()
model.add(layers.Dense(16, activation='relu', input_shape=(10000,)))
model.add(layers.Dense(16, activation='relu'))
model.add(layers.Dense(1, activation='sigmoid'))
```

Version of the model with lower capacity

```
model = models.Sequential()
model.add(layers.Dense(4, activation='relu', input_shape=(10000,)))
model.add(layers.Dense(4, activation='relu'))
model.add(layers.Dense(1, activation='sigmoid'))
```

تکنیک‌های رگولاریزاسیون

کاهش اندازه‌ی شبکه: مثال (طبقه‌بندی نقد فیلم‌ها): نمودار اتلاف اعتبارسنجی



Effect of model capacity on validation loss: trying a smaller model

شبکه‌ی کوچکتر، دیرتر از شبکه‌ی اصلی شروع به بیش‌برازش می‌کند (پس از ۶ اپک در مقابل ۴ اپک). و با شروع بیش‌برازش، کارآیی آن کندتر تنزل می‌یابد.

تکنیک‌های رگولاریزاسیون

کاهش اندازه‌ی شبکه: مثال (طبقه‌بندی نقد فیلم‌ها): افزایش ظرفیت شبکه

Original model (the movie-review classification network)


```
from keras import models
from keras import layers
model = models.Sequential()
model.add(layers.Dense(16, activation='relu', input_shape=(10000,)))
model.add(layers.Dense(16, activation='relu'))
model.add(layers.Dense(1, activation='sigmoid'))
```

Version of the model with higher capacity

```
model = models.Sequential()
model.add(layers.Dense(512, activation='relu', input_shape=(10000,)))
model.add(layers.Dense(512, activation='relu'))
model.add(layers.Dense(1, activation='sigmoid'))
```

تکنیک‌های رگولاریزاسیون

کاهش اندازهٔ شبکه: مثال (طبقه‌بندی نقد فیلم‌ها): افزایش ظرفیت شبکه: نمودار اتلاف اعتبارسنجی




Effect of model capacity on validation loss: trying a bigger model

شبکه‌ی بزرگ‌تر، تقریباً بلافاصله پس از اپک اول شروع به بیش‌برازش می‌کند و بیش‌برازش آن بسیار شدید‌تر است.
سیگнал اتلاف اعتبارسنجی نیز نویزی‌تر است.

تکنیک‌های رگولاریزاسیون

کاهش اندازهٔ شبکه: مثال (طبقه‌بندی نقد فیلم‌ها): نمودار اتلاف داده‌های آموزشی



Effect of model capacity on training loss: trying a bigger model

شبکه‌ی بزرگ‌تر در میزان اتلاف داده‌های آموزشی خود سریعاً به نزدیک صفر دست یافته است. هرچه شبکه ظرفیت بیشتری داشته باشد، داده‌های آموزشی را سریع‌تر می‌تواند مدل کند (منجر به اتلاف کمتر) اما به بیش‌برازش بیشتر مشکوک می‌شود (در اثر اختلاف بزرگ بین اتلاف‌های آموزشی و اعتبارسنجی).

تکنیک‌های رگولاریزاسیون

اصل تیغه‌ی او خامی

OCKHAM'S RAZOR

اصل تیغه‌ی او خامی

Ockham's Razor

ساده‌ترین مدلی که داده‌ها را توضیح می‌دهد، بیابید.

Find the simplest model that explains the data.

هرچه مدل پیچیده‌تر باشد، امکان خطأ بیشتر می‌شود.

وقتی دو توضیح برای چیزی داده شده باشد، توضیحی که ساده‌تر است شанс بیشتری برای درست بودن دارد.
(توضیحی که فرضیات کمتری را در نظر می‌گیرد.)

استفاده از این ایده در مدل‌هایی که با شبکه‌های عصبی یاد گرفته می‌شوند:

با داشتن مقداری داده‌های آموزشی و یک معماری شبکه،

چندین مجموعه از مقادیر وزن‌ها (چندین مدل‌ها) می‌توانند داده‌ها را توضیح دهند.

مدل‌های ساده‌تر کمتر از مدل‌های پیچیده شانس گرفتار شدن در بیش‌بازش را دارند.

تکنیک‌های رگولاریزاسیون

افزودن رگولاریزاسیون وزنی

ADDING WEIGHT REGULARIZATION

مدل‌های ساده‌تر کمتر از مدل‌های پیچیده شناس گرفتار شدن در بیش‌برازش را دارند. مدل ساده‌تر در این مضمون، مدلی است که در آن توزیع مقادیر پارامتر آنتروپی کمتری داشته باشد. (یا مدلی که تعداد پارامتر کمتری داشته باشد.)

پس یک راه متداوی کاهش بیش‌برازش، قرار دادن قیدهایی بر روی پیچیدگی یک شبکه است:

مجبر کردن وزن‌های شبکه به اینکه تنها مقادیر کوچک را بپذیرند

توزیع مقادیر وزن‌ها منظم‌تر می‌شود (more regular) ⇐ رگولاریزاسیون وزنی

اضافه کردن یک مقدار هزینه مرتبط با داشتن وزن‌های بزرگ
به تابع اتلاف شبکه

رگولاریزاسیون وزنی
Weight Regularization

- رگولاریزاسیون ال۱ [the L1 norm of the weights] (L1 regularization) : هزینه‌ی اضافه شده به اتلاف متناسب با قدر مطلق مقدار ضرایب وزنی است.
- رگولاریزاسیون ال۲ [the L2 norm of the weights] (L2 regularization) : هزینه‌ی اضافه شده به اتلاف متناسب با مجدور مقدار ضرایب وزنی است.

انواع متداوی
رگولاریزاسیون
وزنی

Regularization: Add term to loss

$$L = \frac{1}{N} \sum_{i=1}^N \sum_{j \neq y_i} \max(0, f(x_i; W)_j - f(x_i; W)_{y_i} + 1) + \boxed{\lambda R(W)}$$

In common use:

L2 regularization

$$R(W) = \sum_k \sum_l W_{k,l}^2 \quad (\text{Weight decay})$$

L1 regularization

$$R(W) = \sum_k \sum_l |W_{k,l}|$$

Elastic net (L1 + L2)

$$R(W) = \sum_k \sum_l \beta W_{k,l}^2 + |W_{k,l}|$$

تکنیک‌های رگولاریزاسیون

افزودن رگولاریزاسیون وزنی در کراس

In Keras, weight regularization is added by passing weight regularizer instances to layers as keyword arguments.

Let's add L2 weight regularization to the movie-review classification network.

Adding L2 weight regularization to the model

```
from keras import regularizers
```


```
model = models.Sequential()
model.add(layers.Dense(16, kernel_regularizer=regularizers.l2(0.001),
                      activation='relu', input_shape=(10000,)))
model.add(layers.Dense(16, kernel_regularizer=regularizers.l2(0.001),
                      activation='relu'))
model.add(layers.Dense(1, activation='sigmoid'))
```

`l2(0.001)` means every coefficient in the weight matrix of the layer will add `0.001 * weight_coefficient_value` to the total loss of the network.

تذکر: جریمه‌ی رگولاریزاسیون تنها در زمان آموزش اضافه می‌شود، برای همین میزان اتلاف شبکه در زمان آموزش بسیار بزرگ‌تر از زمان تست است.

تکنیک‌های رگولاریزاسیون

افزودن رگولاریزاسیون وزنی در کراس: نمودار اتلاف اعتبارسنجی



Effect of L2 weight regularization on validation loss

مدل دارای رگولاریزاسیون L2 نسبت به مدل مرجع در برابر بیشتر برآذش مقاومت می‌کند.
اگرچه هر دو مدل تعداد یکسانی پارامتر دارند.

تکنیک‌های رگولاریزاسیون

افزودن رگولاریزاسیون وزنی در کراس: گزینه‌ها

As an alternative to L2 regularization,
you can use one of the following **Keras** weight regularizers.

Different weight regularizers available in Keras

```
from keras import regularizers
regularizers.l1(0.001)                      # L1 regularization
regularizers.l1_l2(l1=0.001, l2=0.001) # Simultaneous L1 and L2 regularization
```

تکنیک‌های رگولاریزاسیون

اضافه کردن بروان اندازی

ADDING DROPOUT

برون اندازی Dropout یکی از مؤثرترین و متدائل‌ترین تکنیک‌های رگولاریزاسیون برای شبکه‌های عصبی است.
 (توسعه یافته توسط هینتون و دانشجویان او در دانشگاه تورنتو)

اعمال Dropout به یک لایه، عبارت است از حذف تصادفی (صفر کردن)
 تعدادی از ویژگی‌های خروجی آن لایه در هنگام آموزش

برون اندازی
Dropout

[0.2, 0.5, 1.3, 0.8, 1.1] Dropout [0, 0.5, 1.3, 0, 1.1]

کسر تعداد ویژگی‌هایی که صفر شده و خارج می‌شوند.
 این مقدار معمولاً بین 0.2 و 0.5 است.



نرخ بروان اندازی
Dropout Rate

در زمان تست، هیچ واحدی dropout نمی‌شود؛
 در عوض، خروجی لایه‌ها با فاکتوری برابر با نرخ dropout مقیاس می‌شوند.
 (برای متعادل‌سازی بر اساس این واقعیت که تعداد واحدهای بیشتری نسبت به زمان آموزش فعال است.)

Regularization: Dropout


In each forward pass, randomly set some neurons to zero

Probability of dropping is a hyperparameter; 0.5 is common



Regularization: Dropout

How can this possibly be a good idea?




Forces the network to have a redundant representation;
Prevents co-adaptation of features



Regularization: Dropout

How can this possibly be a good idea?



Another interpretation:

Dropout is training a large **ensemble** of models (that share parameters).

Each binary mask is one model

An FC layer with 4096 units has $2^{4096} \sim 10^{1233}$ possible masks!
Only $\sim 10^{82}$ atoms in the universe...

Dropout: Test time

Dropout makes our output random!

$$\boxed{y} = f_W(\boxed{x}, \boxed{z})$$

Output
(label) Input
(image) Random
mask

Want to “average out” the randomness at test-time

$$y = f(x) = E_z[f(x, z)] = \int p(z)f(x, z)dz$$


But this integral seems hard ...

Dropout: Test time

Want to approximate
the integral

$$y = f(x) = E_z[f(x, z)] = \int p(z)f(x, z)dz$$

Consider a single neuron.



At test time we have: $E[a] = w_1x + w_2y$

During training we have:

$$\begin{aligned} E[a] &= \frac{1}{4}(w_1x + w_2y) + \frac{1}{4}(w_1x + 0y) \\ &\quad + \frac{1}{4}(0x + 0y) + \frac{1}{4}(0x + w_2y) \\ &= \frac{1}{2}(w_1x + w_2y) \end{aligned}$$

At test time, multiply
by dropout probability

Dropout: Test time

```
def predict(X):
    # ensembled forward pass
    H1 = np.maximum(0, np.dot(W1, X) + b1) * p # NOTE: scale the activations
    H2 = np.maximum(0, np.dot(W2, H1) + b2) * p # NOTE: scale the activations
    out = np.dot(W3, H2) + b3
```

At test time all neurons are active always

=> We must scale the activations so that for each neuron:
output at test time = expected output at training time

تکنیک‌های رگولاریزاسیون

اضافه کردن بروان اندازی

Consider a Numpy matrix containing the output of a layer, `layer_output`, of shape (`batch_size, features`).

At training time, we zero out at random a fraction of the values in the matrix:

```
layer_output *= np.random.randint(0, high=2, size=layer_output.shape)
# At training time, drops out 50% of the units in the output
```

At test time, we scale down the output by the dropout rate. Here, we scale by 0.5 (because we previously dropped half the units):


```
layer_output *= 0.5                                # At test time
```

تکنیک‌های رگولاریزاسیون

اضافه کردن بروان اندازی

Note that this process can be implemented by doing both operations at training time and leaving the output unchanged at test time, which is often the way it's implemented in practice:

```
layer_output *= np.random.randint(0, high=2, size=layer_output.shape)           # At training time
layer_output /= 0.5
# Note that we're scaling up rather scaling down in this case.
```



Dropout applied to an activation matrix at training time,
with rescaling happening during training.

At test time, the activation matrix is unchanged.

تکنیک‌های رگولاریزاسیون

اضافه کردن برون‌اندازی: منشأ ایده

تکنیک برون‌اندازی / Dropout ممکن است عجیب و دلخواهی به نظر برسید.

چرا این تکنیک بیش‌برازش را کاهش می‌دهد؟

هینتون بیان می‌کند که این روش را

غیر از سایر موارد، از یک **مکانیسم پیشگیری از کلاهبرداری در بانک‌ها** ایده گرفته است:

«من به بانک رفته بودم، تحويل‌دارها جای خود را با یکدیگر عوض کرده بودند و من دلیل این کار را از یکی از آنها پرسیدم. او گفت که نمی‌داند، اما آنها زیاد جای خود را تغییر می‌دهند.


من با خودم فکر کردم که دلیل آن حتماً این است که پیشگیری موفقیت‌آمیز از کلاهبرداری از بانک نیازمند همکاری بین کارمندان است. این نکته باعث شد تا متوجه بشوم تغییر مکان تصادفی یک زیرمجموعه‌ی متفاوت از نرون‌ها در هر مثال می‌تواند مانع از توطئه و دسیسه شود و بنابراین بیش‌برازش را کاهش می‌دهد.»

ایده و مفهوم اصلی:

وارد کردن نویز در مقادیر خروجی یک لایه،

می‌تواند سبب شود الگوهای اتفاقی که چشمگیر نیستند (توطئه‌ها) بشکنند

اما اگر هیچ تداخل و نویزی وجود نداشته باشد، شبکه شروع به حفظ کردن داده‌ها می‌کند (بیش‌برازش).



تکنیک‌های رگولاریزاسیون

اضافه کردن Dropout در کراس

In **Keras**, you can introduce dropout in a network via the Dropout layer, which is applied to the output of the layer right before it

```
model.add(layers.Dropout(0.5))
```


Let's add two Dropout layers in the IMDB network to see how well they do at reducing overfitting.

Adding dropout to the IMDB network

```
model = models.Sequential()  
model.add(layers.Dense(16, activation='relu', input_shape=(10000,)))  
model.add(layers.Dropout(0.5))  
model.add(layers.Dense(16, activation='relu'))  
model.add(layers.Dropout(0.5))  
model.add(layers.Dense(1, activation='sigmoid'))
```

تکنیک‌های رگولاریزاسیون

اضافه کردن Dropout: نمودار اعتبارسنجی



Effect of dropout on validation loss

این نمودار بیانگر پیشرفت آشکاری نسبت به شبکه‌ی مرجع است.

جمع‌بندی: اجتناب از بیش‌برازش در شبکه‌های عصبی

RECAP: TO PREVENT OVERFITTING IN NEURAL NETWORKS

متداول‌ترین روش‌ها برای جلوگیری از بروز بیش‌برازش در شبکه‌های عصبی:



مبانی یادگیری ماشینی

۵

گرددش کار
جامع
در
یادگیری
ماشینی

گردش کار جامع در یادگیری ماشینی

THE UNIVERSAL WORKFLOW OF MACHINE LEARNING



گردش کار جامع در یادگیری ماشینی

تعریف مسئله و گردآوری مجموعه داده

DEFINING THE PROBLEM AND ASSEMBLING A DATASET

تعریف مسئله و گردآوری مجموعه داده

Defining the problem and assembling a dataset

۱

- داده‌های ورودی؟ چه چیزی باید پیش‌بینی شود؟
- ورودی؟ خروجی؟
- نوع مسئله؟ (طبقه‌بندی دودویی، رگرسیون، خوش‌بندی، تولید، ...)

تعریف مسئله

شناسایی نوع مسئله، در انتخاب مدل، تابع اتلاف و ... ما را راهنمایی می‌کند.

- فرض می‌شود که می‌توان خروجی‌ها را بر اساس ورودی‌های آنها پیش‌بینی کرد.
[وجود رابطه‌ی تابعی بین ورودی‌ها و خروجی‌ها]

فرضیات
اساسی

- فرض می‌شود که داده‌های موجود حاوی اطلاعات کافی برای یادگیری رابطه‌ی بین ورودی‌ها و خروجی‌ها هستند. [میزان داده‌ی کافی]

گرددش کار جامع در یادگیری ماشینی

تعریف مسئله و گردآوری مجموعه داده: مسائل حل ناپذیر

UNSOLVABLE PROBLEMS

مسائلی که هدف از آنها کشف تابعی است که خاصیت آن با زمان تغییر می‌کند.

مسائل غیرایستان
Nonstationary Problems

مثال: مسئله‌ی سیستم توصیه‌گر لباس
توصیه متناسب با زمان سال متغیر است،
پس داده‌های آموزشی باید حاوی ویژگی زمان سال باشند.

گرددش کار جامع در یادگیری ماشینی

تعریف مسئله و گردآوری مجموعه داده: محدودیت‌ها

یادگیری ماشینی تنها می‌تواند

برای حفظ کردن الگوهایی که در مجموعه داده‌های آموزشی حاضر است استفاده شود.

«چیزی را می‌توانیم بازشناسی کنیم که قبل آن را دیده باشیم»

استفاده از یادگیری ماشینی آموزش دیده بر روی داده‌های گذشته برای پیش‌بینی آینده،
این فرض را در خود دارد که:
«آینده مانند گذشته رفتار می‌کند»
که خیلی اوقات برقرار نیست!

گرددش کار جامع در یادگیری ماشینی

انتخاب یک معیار موفقیت

CHOOSING A MEASURE OF SUCCESS

انتخاب یک معیار موفقیت

Choosing a measure of success

۲

برای اینکه بتوان چیزی را کنترل کرد، باید بتوان آن را مشاهده کرد.

برای دستیابی به موفقیت باید آن را تعریف کنیم: دقیق؟ یادآوری؟ نرخ حفظ مشتری؟ ...

معیار موفقیت، راهنمایی برای انتخاب یک تابع هزینه خواهد بود.

- برای مسائل طبقه‌بندی متوازن (احتمال کلاس‌ها مساوی)، صحت (Accuracy) و سطح زیر منحنی ROC یک معیار متدائل است (ROC AUC).
- برای مسائل طبقه‌بندی نامتوازن (احتمال کلاس‌ها نامساوی)، دقیق (Precision) و یادآوری (Recall) متدائل است.
- برای مسائل رتبه‌بندی یا طبقه‌بندی چندبرچسبی، میانگین دقیق متوسط (MAP) متدائل است.

تعریف معیار موفقیت اختصاصی برای کاربردهای گوناگون، متدائل است.

گردش کار جامع در یادگیری ماشینی

تصمیم‌گیری در مورد پروتکل ارزیابی

DECIDING ON AN EVALUATION PROTOCOL

تصمیم‌گیری در مورد پروتکل ارزیابی

Deciding on an evaluation protocol

۳

وقتی که هدف مشخص شد، باید شیوه‌ای برای **سنجه پیشرفته فرآیند یادگیری** مشخص شود.

سه پروتکل متداول برای ارزیابی داریم:

روش مناسب برای زمانی که حجم فراوانی داده در اختیار داریم.
(در بیشتر موارد این روش به اندازه‌ی کافی خوب است)

اعتبارسنجی ساده نگهداشت-برونگذاشت
Simple Hold-Out Validation

انتخاب درست برای موقعی که نمونه‌های بسیار اندکی در اختیار داریم و روش ساده اطمینان‌بخش نیست.

K-fold اعتبارسنجی
K-fold Validation

برای اجرای ارزیابی بسیار دقیق مدل در زمانی که داده‌های کمی در دسترس است.

اعتبارسنجی K-fold تکراری با بُر زدن
Iterated K-fold Validation with Shuffling

گرددش کار جامع در یادگیری ماشینی

آماده‌سازی داده‌ها

PREPARING THE DATA

آماده‌سازی داده‌ها

Preparing the data

۳

ابتدا باید داده‌ها را به گونه‌ای که بتوانند وارد یک مدل یادگیری ماشینی (در اینجا شبکه‌ی عصبی) شوند، فرمت‌بندی کنید.

- داده‌ها باید در قالب تانسورها فرمت‌بندی شوند.
- مقادیر موجود در تانسورها باید در قالب اعداد کوچک مقیاس شوند.
(بازه‌ی $[0,1]$ یا $[-1,1]$)
- نرمال‌سازی مستقل ویژگی‌ها برای داده‌های ناهمگن
- انجام مهندسی ویژگی‌ها به خصوص برای مسائلی با داده‌های کوچک

فرمت‌بندی
برای
آماده‌سازی داده‌ها

زمانی که تانسورهای داده‌های ورودی و تارگت آماده شدند، می‌توانیم آموزش مدل را شروع کنیم.

گرددش کار جامع در یادگیری ماشینی

توسعه‌ی یک مدل که بهتر از یک مدل پایه عمل کند

DEVELOPING A MODEL THAT DOES BETTER THAN A BASELINE

توسعه‌ی یک مدل که بهتر از یک مدل پایه عمل کند

Developing a model that does better than a baseline

۵

هدف این مرحله، توسعه‌ی مدلی است که به قدرت آماری دست پیدا کند.

مدلی دارای قدرت آماری است که
 قادر به شکست دادن یک مدل پایه‌ی تصادفی باشد.

قدرت آماری
Statistical Power

برای مثال: مدل پایه تصادفی برای مسئله‌ی طبقه‌بندی دو کلاسی دارای دقت $\frac{1}{2} = 0.5$ است.
مدل پایه تصادفی برای مسئله‌ی طبقه‌بندی n -کلاسی دارای دقت $\frac{1}{n}$ است.

دستیابی به مدلی با قدرت آماری، همیشه ممکن نیست.

اگر پس از آزمایش چندین معماری مستدل نتوانیم مدل پایه‌ی تصادفی را شکست دهیم،
ممکن است به این دلیل باشد که پاسخ پرسشی که به دنبال آن هستیم در داده‌های ورودی وجود ندارد.
یا ممکن است فرضیات اساسی (وجود رابطه‌ی تابعی / داده‌ی کافی) نادرست باشند.

گرددش کار جامع در یادگیری ماشینی

توسعه‌ی یک مدل که بهتر از یک مدل پایه عمل کند: پارامترها

با فرض درست بودن فرضیات اولیه،
باید در مورد سه انتخاب کلیدی برای ساختن اولین مدل کاری خود تصمیم‌گیری کنید:

- | | |
|---|--|
| <ul style="list-style-type: none"> ○ تابع فعالیت لایه‌ی آخر [بر اساس نوع خروجی شبکه] ○ تابع اتلاف [لزوم مطابقت با مسئله‌ی مورد نظر] ○ پیکربندی بهینه‌ساز (الگوریتم بهینه‌سازی، نرخ یادگیری آن، ...) | سه انتخاب کلیدی
برای
ساختن
اولین مدل کاری |
|---|--|

با توجه به انتخاب تابع اتلاف، همواره امکان بهینه‌سازی مستقیم برای معیارهای موفقیت مسئله وجود ندارد.
در برخی موارد هیچ راه آسانی برای تبدیل یک معیار موفقیت به یک تابع هزینه وجود ندارد.
تابع اتلاف باید برای یک دسته‌ی کوچک از داده‌ها قابل محاسبه باشد.
تابع اتلاف باید حتی برای یک نقطه هم قابل محاسبه باشد.
تابع اتلاف باید مشتق‌پذیر باشد تا بتوان از آن در الگوریتم پس‌انتشار خطأ استفاده کرد.
[برای مثال معیار **ROC AUC** مشتق‌پذیر نیست]
و برای همین در مسائل طبقه‌بندی از معیارهای نماینده‌ی آن مانند آنتروپی متقابل استفاده می‌شود.]

گردش کار جامع در یادگیری ماشینی

توسعه‌ی یک مدل که بهتر از یک مدل پایه عمل کند: انتخاب تابع فعالیت و تابع اتلاف برای مسائل گوناگون

Problem type	Last-layer activation	Loss function
Binary classification	sigmoid	binary_crossentropy
Multiclass, single-label classification	softmax	categorical_crossentropy
Multiclass, multilabel classification	sigmoid	binary_crossentropy
Regression to arbitrary values	None	mse
Regression to values between 0 and 1	sigmoid	mse or binary_crossentropy

گرددش کار جامع در یادگیری ماشینی

افزایش مقیاس: توسعه‌ی یک مدل که بیشبرازش کند

SCALING UP: DEVELOPING A MODEL THAT OVERFITS

افزایش مقیاس: توسعه‌ی یک مدل که بیشبرازش کند

Scaling up: developing a model that overfits

۶

وقتی به مدلی رسیدیم که دارای قدرت آماری است، این پرسش مطرح می‌شود که:

آیا این مدل به اندازه‌ی کافی قدرتمند است؟

[تعداد لایه‌ها و واحدها کافی است؟ ...]

کشمکش اساسی در یادگیری ماشینی بین سازگاری و تعمیمدهی است.
مدل ایده‌آل، مدلی است که درست در مرز میان کم‌برازش و بیش‌برازش قرار بگیرد:

مرز میان کم‌ظرفیتی و بیش‌ظرفیتی؛

برای پیدا کردن این مرز ابتدا باید از آن عبور کنیم.

- لایه‌هارا اضافه می‌کنیم.
- لایه‌هارا بزرگ‌تر می‌کنیم.
- فرآیند آموزش را طی اپکهای بیشتری تکرار می‌کنیم.

برای تعیین بزرگی مدل مورد نیاز،
باید مدلی ایجاد کرد که دچار
بیش‌برازش شود:

اتلاف روی داده‌های آموزشی و اعتبارسنجی را تحت نظارت قرار می‌دهیم.
هنگامی که کارآیی مدل روی داده‌های اعتبارسنجی شروع به افت کرد، به بیش‌برازش رسیده‌ایم.

گرددش کار جامع در یادگیری ماشینی

رگولاریزاسیون مدل و تنظیم هایپرپارامترها

REGULARIZING THE MODEL AND TUNING YOUR HYPERPARAMETERS

رگولاریزاسیون مدل و تنظیم هایپرپارامترها

Regularizing the model and tuning your hyperparameters

۷

این مرحله بیشترین زمان را صرف می‌کند: مدل باید به طور مکرر اصلاح شود، تحت آموزش مجدد قرار گیرد و روی داده‌های اعتبارسنجی ارزیابی شود. مجدداً مدل اصلاح می‌شود و تکرار می‌شود تا زمانی که مدل به بهترین حالت برسد.

موارد
قابل امتحان کردن

- اضافه کردن برواندمازی / Dropout
- آزمون معماری‌های مختلف: اضافه / حذف لایه‌ها
- اضافه کردن رگولاریزاسیون وزنی
- آزمون هایپرپارامترهای مختلف (تعداد واحد هر لایه / نرخ یادگیری بهینه‌ساز، ...)
- مهندسی ویژگی‌ها: اضافه کردن ویژگی جدید، حذف ویژگی غیرمفید

نکته‌ی مهم: هر زمان که فیدبک فرآیند اعتبارسنجی برای تنظیم مدل استفاده می‌شود، مقداری **نشت اطلاعات** در مورد فرآیند اعتبارسنجی به درون مدل داریم. اگر تنها چند بار این اتفاق رخ دهد، خطری ندارد، اما اگر به طور منظم و به دفعات رخ بددهد، سرانجام منجر به بیشبرازش مدل نسبت به فرآیند اعتبارسنجی می‌شود. در نتیجه فرآیند ارزیابی، قابلیت اطمینان کمتری خواهد داشت.

گرددش کار جامع در یادگیری ماشینی

پایان کار

وقتی به یک پیکربندی راضی‌کننده برای مدل رسیدیم،
مدل نهایی را روی **تمام داده‌های موجود (آموزشی و اعتبارسنجی)** مورد آموزش قرار می‌دهیم
و آن را برای آخرین بار روی مجموعه‌ی آزمایشی ارزیابی می‌کنیم.

اگر مشخص شود که کارآیی در مجموعه‌ی آزمایشی خیلی بدتر از کارآیی در مجموعه‌ی آموزشی است،
ممکن است به این معنا باشد که روال اعتبارسنجی مورد استفاده قابل اطمینان نبوده است،
یا در هنگام تنظیم پارامترهای مدل شروع به بیش‌برازش نسبت به داده‌های اعتبارسنجی کرده است.
در این حالت باید به سراغ یک پروتکل ارزیابی با قابلیت اطمینان بالاتر برویم.

مبانی یادگیری ماشینی

خلاصه

- ❖ Define the **problem** at hand and the **data** on which you'll train.
Collect this data, or annotate it with labels if need be.
- ❖ Choose how you'll **measure success** on your problem.
Which metrics will you monitor on your validation data?
- ❖ Determine your **evaluation protocol**: hold-out validation? K-fold validation?
Which portion of the data should you use for validation?
- ❖ Develop a first model that does better than a basic baseline:
a model with statistical power.
- ❖ Develop a model that **overfits**.
- ❖ **Regularize** your model and tune its hyperparameters, based on performance on the validation data. A lot of machine-learning research tends to focus only on this step—but keep the big picture in mind.

مبانی یادگیری ماشینی

۶

منابع

منبع اصلی

*Deep Learning
with Python*

FRANÇOIS CHOLLET



François Chollet,
Deep Learning with Python,
 Manning Publications, 2018.

Chapter 4*Fundamentals of
machine learning****This chapter covers***

- Forms of machine learning beyond classification and regression
- Formal evaluation procedures for machine-learning models
- Preparing data for deep learning
- Feature engineering
- Tackling overfitting
- The universal workflow for approaching machine-learning problems

After the three practical examples in chapter 3, you should be starting to feel familiar with how to approach classification and regression problems using neural networks, and you've witnessed the central problem of machine learning: overfitting. This chapter will formalize some of your new intuition into a solid conceptual framework for attacking and solving deep-learning problems. We'll consolidate all of these concepts—model evaluation, data preprocessing and feature engineering, and tackling overfitting—into a detailed seven-step workflow for tackling any machine-learning task.